

Efektywny algorytm wyznaczający miarę podobieństwa wyrazów za pomocą uogólnionej metody n -gramów (miary Niewiadomskiego)

prof. dr hab. Stanisław Goldstein
Uniwersytet Łódzki

mgr inż. Piotr Beling
Uniwersytet Łódzki

24 września 2012

Streszczenie

W artykule przedstawiono efektywny (dynamiczny) algorytm wyznaczający miarę podobieństwa wyrazów za pomocą uogólnionej metody n -gramów (miary Niewiadomskiego [2]). Uzasadniono także poprawność działania algorytmu i oszacowano jego złożoność obliczeniową.

Abstract

This article presents effective (dynamic) algorithm for solving a problem of counting the number of substrings of given string which are also substrings of second string. Presented algorithm can be used for example for quick calculation of strings similarity measure using generalized n -gram method (Niewiadomski measure [2]), which are shown. Correctness and complexity analyses are included.

1 Oznaczenia

Jeśli przez w , s będą oznaczone słowa, to:

- $|w|$ - długość słowa w (liczba liter),
- litery w słowie w mają indeksy od 0 do $|w| - 1$,
- $w[a..b]$ (dla $a, b \in \mathbb{N}$) - podsłowo słowa w od litery a -tej do b -tej (włącznie) lub słowo puste gdy $a > b$,
- $w[a..b)$ (dla $a, b \in \mathbb{N}$) - podsłowo $w[a..b - 1]$ słowa w ,
- $w[a..)$ (dla $a \in \mathbb{N}$) - podsłowo $w[a..|a|)$ (sufiks słowa w rozpoczynający się od a -tej litery),
- $w[a]$ (dla $a \in \mathbb{N}$) a -ta litera słowa w ($w[a] = w[a..a]$),
- ws - konkatencja słów w i s , tj. słowo długości $|w| + |s|$, takie, że $(ws)[0..|w|) = w$ i $(ws)[|w|..) = s$;
- zachodzi $w = w[0..|w| - 1] = w[0..|w|) = w[0..) = w[0]w[1] \dots w[|w| - 1]$.

2 Metoda n -gramów

Metody n -gramów (1-gramów czyli unigramów, 2-gramów czyli bigramów, 3-gramów czyli trigramów, itd.) są popularnymi technikami analizy tekstów o szerokich możliwościach zastosowania, por. np. [4, 5, 6, 7, 8, 9].

Miary n -gramów bazują na zliczaniu n -literowych słów (zwanymi n -gramami) będących równocześnie pod słowami obu porównywanych słów. Im więcej wspólnych n -gramów mają porównywane słowa tym bardziej są do siebie podobne. Więcej szczegółów można znaleźć w artykule [1].

3 Uogólniona miara n -gramów

Uogólnienie miar n -gramów polegające na zliczaniu pod słów dowolnej długości zaproponował A. Niewiadomski w rozprawie [2].

Podobieństwo słów w_1 i w_2 wg. uogólnionej miary n -gramów wynosi $\min(\text{sim}(w_1, w_2), \text{sim}(w_2, w_1))$, przy czym funkcja sim zdefiniowana jest następująco:

$$\text{sim}(w_1, w_2) = \frac{2}{N^2 + N} \sum_{i=1}^{\min(|w_1|, |w_2|)} \sum_{j=0}^{|w_1|-i} h(i, j) \quad (1)$$

gdzie:

- $N = \max(|w_1|, |w_2|)$
- $h(i, j) = \begin{cases} 1, & \text{gdy } w_1[j..j+i] \text{ jest pod słowem } w_2 \\ 0, & \text{w przeciwnym razie} \end{cases}$

Funkcja sim liczy iloraz:

- liczbę (niekoniecznie różnych) pod słów w_1 będących równocześnie pod słowami w_2 , przez:
- liczbę wszystkich (niekoniecznie różnych) pod słów dłuższego ze słów: w_1, w_2 (jest ich $\frac{N^2+N}{2}$).

Funkcja sim nie jest symetryczna.

Miara Niewiadomskiego może być zastosowana do porównywania dowolnych ciągów liter, zarówno całych dokumentów tekstowych, całych zdań, fraz lub pojedynczych wyrazów. Jej przydatność w praktyce potwierdził m.in. J. Adamczak w pracy [3]. Wykorzystał on ją w budowie systemu ekspertowego wspomagającego diagnostykę medyczną. Zadaniem jego opartego o logikę rozmytą, regułowego systemu było porównanie (sklasyfikowanie) nowego, opisanego stanem pacjenta przypadku z zawartymi w bazie zdiagnozowanymi przypadkami oraz podanie zbioru możliwych diagnoz.

4 Algorytm naiwny i jego złożoność

Oznaczmy: $a = |w_1|$, $b = |w_2|$. Algorytm naiwny¹² wyznaczający wartość funkcji sim wprost ze wzoru 1 wykona (w pesymistycznym przypadku) następującą ilość porównań symboli:

$$\sum_{i=1}^{\min(a,b)} (a-i+1)(b-i+1)i$$

Ze względu na symetryczność powyższego wzoru, możemy, bez straty ogólności obliczeń założyć, że $\min(a, b) = a$, mamy wtedy:

$$\begin{aligned} \sum_{i=0}^{a-1} (a-i)(b-i)(i+1) &= \sum_{i=0}^{a-1} (ab - ai - bi + i^2)(i+1) = \\ ab \sum_{i=0}^{a-1} (i+1) - (a+b) \sum_{i=0}^{a-1} i(i+1) + \sum_{i=0}^{a-1} i^2(i+1) &= \\ ab \sum_{i=1}^a i - (a+b) \sum_{i=1}^a (i^2 - i) + \sum_{i=0}^{a-1} i^3 + \sum_{i=0}^{a-1} i^2 &= \\ \frac{aba(a+1)}{2} - (a+b) \sum_{i=1}^a i^2 + (a+b) \sum_{i=1}^a i + \left(\frac{(a-1)a}{2}\right)^2 + \sum_{i=1}^a i^2 - a^2 &= \\ \frac{a^3b + a^2b}{2} - (a+b+1) \frac{a(a+1)(2a+1)}{6} + \frac{(a+b)a(a+1)}{2} + \left(\frac{a^2-a}{2}\right)^2 - a^2 &= \\ \frac{1}{12} (2a^3b + 6a^2b - a^4 - 10a^3 - 11a^2 - 8ab - 2a) &= \Theta(a^3b) \end{aligned}$$

Stąd, złożoność czasowa algorytmu naiwnego wynosi $\Theta(|w_1||w_2| \min(|w_1|, |w_2|))$. Jego złożoność pamięciowa to $\Theta(1)$.

Algorytm naiwny można poprawić używając w jego konstrukcji algorytmu wyszukiwającego wzorca w czasie liniowym (np. Knutha-Morrisa-Pratta). Otrzymamy wtedy algorytm o złożoności czasowej $\Theta(|w_1||w_2| \min(|w_1|, |w_2|))$.

5 Algorytm efektywny i jego złożoność

Oznaczmy: $\text{sc}(w_1, w_2) = \sum_{i=1}^{\min(|w_1|, |w_2|)} \sum_{j=0}^{|w_1|-i} h(i, j)$ (zachodzi: $\text{sim}(w_1, w_2) = \frac{2}{N^2+N} \text{sc}(w_1, w_2)$). $\text{sc}(w_1, w_2)$ to ilość (niekoniecznie różnych) podsłów w_1 będących równocześnie podsłowami w_2 .

Lemat 1 (o funkcji h). *Jeśli $h(i, j) = 1$ to dla dowolnego $y < i$: $h(y, j) = 1$.*

Dowód. Jeśli $h(i, j) = 1$ to $w_1[j..j+i]$ jest pod słowem w_2 , tzn. istnieje w w_2 pozycja x taka, że $w_1[j..j+i] = w_2[x..x+i]$, stąd zaś $w_1[j..j+i-1] = w_2[x..x+i-1]$ (czyli $h(i-1, j)=1$), $w_1[j..j+i-2] = w_2[x..x+i-2]$ (czyli $h(i-2, j)=1$), itd. $\square$

Z lematu 1 wynika, że dla dowolnego j istnieje $i \in \{0, 1, \dots\}$, takie, że:

¹Sprawdzający (dla kolejnych długości $i = 1, 2, \dots, \min(a, b)$) kolejno wszystkie pod słowem i -literowe słowa w_1 (jest ich $a-i+1$) czy są podsłowami w_2 . Jest $b-i+1$ i -literowych podsłów w_2 . Porównanie dwóch słów długości i może (w razie równości) wymagać i porównań symboli.

²użyty m.in. w implementacji systemu ekspertowego przez J. Adamczaka [3]

- $h(y, j) = 1$ dla dowolnego $y \leq i$,
- $h(y, j) = 0$ dla dowolnego $y > i$.

Inaczej mówiąc, dla danego indeksu j początku podsłowa w_1 można znaleźć największą jego długość i , taką że:

- $w_1[j..j], w_1[j..j+1], \dots, w_1[j..j+i]$ są podsłowami w_2 ,
- $w_1[j..j+i], w_1[j..j+i+1], \dots, w_1[j..|w_1|)$ nie są podsłowami w_2 .

Oznaczmy tą liczbę symbolem $\text{maxlen}(w_1, w_2, j)$.

Można policzyć liczbę $\text{sc}(w_1, w_2)$ jako sumę:

$$\text{sc}(w_1, w_2) = \sum_{j=0}^{|w_1|-1} \text{maxlen}(w_1, w_2, j) \quad (2)$$

Rozważmy kolejne sufiksy słowa w_1 : $p_1 = w_1[|w_1| - 1..], p_2 = w_1[|w_1| - 2..], \dots, p_i = w_1[|w_1| - i..]$. Zachodzi $|p_i| = i$.

Niech simlen będzie funkcją taką, że $\text{simlen}(w_1, w_2, n, l) = x$ wtedy i tylko wtedy, gdy: $p_n[0..x] = w_2[l..l+x]$ oraz (w przypadku gdy $x \neq n$) $p_n[x] \neq w_2[l+x]$.

Czyli $\text{simlen}(w_1, w_2, n, l) = x$ gdy słowa p_n i $w_2[l..]$ mają dokładnie x pierwszych takich samych liter (tj. ich najdłuższy wspólny prefiks ma długości x).

Przyjmijmy dodatkowo $\text{simlen}(w_1, w_2, 0, l) = 0$ dla dowolnego l .

Lemat 2. Dla $n > 0$:

- $\text{simlen}(w_1, w_2, n, l) = 0$ gdy $p_n[0] \neq w_2[l]$
- $\text{simlen}(w_1, w_2, n, l) = 1 + \text{simlen}(w_1, w_2, n-1, l+1)$ gdy $p_n[0] = w_2[l]$

Dowód. Pierwsza równość wynika wprost z definicji simlen . Druga także z faktów, że $p_n = p_n[0]p_{n-1}$ i $w_2[l..] = w_2[l]w_2[l+1..]$. $\square$

Oznaczmy:

$$\text{simlenmax}(w_1, w_2, n) = \max(\text{simlen}(w_1, w_2, n, 0), \dots, \text{simlen}(w_1, w_2, n, |w_2|-1)) \quad (3)$$

Łatwo zauważyć, że $\text{simlenmax}(w_1, w_2, n) = x$ oznacza, że najdłuższy prefiks słowa p_n będący podsłowem w_2 jest długości x , tj. że $p_n[0..x-1]$ ($= w_1[|w_1| - n..|w_1| - n + x]$) jest podsłowem w_2 i równocześnie (gdy $x \neq |p_n|$) nie jest nim $p_n[0..x]$ ($= w_1[|w_1| - n..|w_1| - n + x]$).

Jeśli więc $\text{simlenmax}(w_1, w_2, n) = x$ to $h(x, |w_1| - n) = 1$ i równocześnie $h(x+1, |w_1| - n) = 0$.

Z lematu 1 także: $h(x-1, |w_1| - n) = 1, h(x-2, |w_1| - n) = 1, \dots, h(1, |w_1| - n) = 1$.

Zachodzi więc $\text{simlenmax}(w_1, w_2, n) = \text{maxlen}(w_1, w_2, |w_1| - n)$ i (na podstawie 2):

$$\text{sc}(w_1, w_2) = \sum_{j=0}^{|w_1|-1} \text{simlenmax}(w_1, w_2, j) \quad (4)$$

```

{funkcja  $sc(w_1, w_2)$ }
{tablica liczb  $simlen$  ma długość  $|w_2| + 1$ }
for  $b = 0$  to  $|w_2|$  do
     $simlen[b] \leftarrow 0$ 
end for
 $result \leftarrow 0$ 
 $alast \leftarrow |w_1|$ 
while  $alast \neq 0$  do
     $alast \leftarrow alast - 1$ 
     $max \leftarrow 0$ 
     $s \leftarrow 0$ 
    for  $b = 0$  to  $|w_2| - 1$  do
        if  $w_2[b] = w_1[alast]$  then
             $simlen[s] \leftarrow simlen[s + 1] + 1$ 
            if  $simlen[s] > max$  then
                 $max \leftarrow simlen[s]$ 
            end if
        else
             $simlen[s] \leftarrow 0$ 
        end if
         $s \leftarrow s + 1$ 
    end for
     $result \leftarrow result + max$ 
end while
return  $result$ 

```

Algorytm 1: dynamiczny algorytm wyznaczający wartość $sc(w_1, w_2)$

```

 $N \leftarrow \max(|w_1|, |w_2|)$ 
return  $2.0 * \min(\text{sc}(w_1, w_2), \text{sc}(w_2, w_1)) / (N * N + N)$ 

```

Algorytm 2: algorytm wyznaczający miarę podobieństwa słów w_1 i w_2 uogólnioną metodą n -gramów, tj. liczący wartość $\min(\text{sim}(w_1, w_2), \text{sim}(w_2, w_1))$

Algorytm 1 wyznacza wartość sc jako sumę $\text{simlenmax}(w_1, w_2, n)$ dla kolejnych $n = 1, 2, \dots, |w_1|$ (zgodnie z 4). Czyni to wykonując $|w_2|$ porównań (dla każdego n) korzystając z programowania dynamicznego i zależności 2. Przy obliczaniu $\text{simlen}(w_1, w_2, n, \dots)$ korzysta z $|w_2|$ wcześniej zapamiętanych wartości $\text{simlen}(w_1, w_2, n - 1, \dots)$, co wymaga użycia $\Theta(|w_2|)$ dodatkowej pamięci.

Algorytmy 1 oraz 2 mają złożoność czasową $\Theta(|w_1||w_2|)$ (wykonują one odpowiednio $|w_1||w_2|$ i $2|w_1||w_2|$ porównań symboli). Pamięciowa złożoność algorytmu 2 to $\Theta(|w_1| + |w_2|)$.

Literatura

- [1] Kondrak Grzegorz, *N-gram similarity and distance*, Proceedings of the Twelfth International Conference on String Processing and Information Retrieval (SPIRE 2005), pp. 115-126, Buenos Aires, Argentina, November 2005.
- [2] Niewiadomski Adam, *Intuicjonistyczne zbiory rozmyte w komputerowym określaniu podobieństwa dokumentów tekstowych*, Rozprawa doktorska, Politechnika Łódzka, Instytut Informatyki, Łódź-Warszawa 2001.
- [3] Adamczak Jakub, *Badanie podobieństwa dokumentów*, Praca magisterska, Politechnika Łódzka, Instytut Informatyki, Łódź 2003.
- [4] Luis Gravano, Panagiotis G. Ipeirotis H. V, Jagadish, Nick Koudas S. Muthukrishnan, Lauri Pietarinen, Divesh Srivastava *Using q-grams in a DBMS for Approximate String Processing*.
- [5] P Majumder, M Mitra, B.B. Chaudhuri *N-gram: a language independent approach to IR and NLP*, International Conference on Universal Knowledge and Language, 2002.
- [6] Anand Natrajan, Allison L. Powell, James C. French *Using N-grams to Process Hindi Queries with Transliteration Variations*, Technical Report, 1997.
- [7] Bruno Martins, Mário J. Silva, *Language Identification in Web Pages*.
- [8] M. N. Karthik, Moshe Davis, *Search Using N-gram Technique Based Statistical Analysis for Knowledge Extraction in Case Based Reasoning Systems*, National Level Mathematics & CS Symposium, Chennai Mathematical Institute (India), ICS '02.
- [9] Wikipedia, the free encyclopedia <http://en.wikipedia.org/wiki/N-gram>.